

## Uma metodologia para aplicação de informações de contexto espacial no aperfeiçoamento de imagens classificadas através da lógica *fuzzy*

Daniel Capella Zanotta<sup>1</sup>

Vitor Haertel<sup>2</sup>

Atilio E. B. Grondona<sup>2</sup>

<sup>1</sup>Divisão de Sensoriamento Remoto - DSR

Instituto Nacional de Pesquisas Espaciais - INPE

Caixa Postal 515 - 12201-970 - São José dos Campos - SP, Brasil

zanotta@dsr.inpe.br

<sup>2</sup>Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia – Universidade

Federal do Rio Grande do Sul - UFRGS - Porto Alegre - RS – Brasil

{vitor.haertel, atilio.grondona}@ufrgs.br

**Abstract.** In the present work, a novel methodology to attribute spatial context information to classification maps generated by fuzzy set approach is proposed and tested. The technique is based in an iterative relaxation process, in which the degree of membership of each pixel to each class is analyzed taking into account its neighborhood membership values. Two experiments were performed with two different kinds of application: a fuzzy based change detection process and a fuzzy maximum likelihood classification with TM-Landsat and CBERS-2B data, respectively. The results showed that the proposed approach was effective to improve the results of the classifications by displaying a most uniform aspect to the fuzzy classification maps.

**Palavras-Chave:** teoria *fuzzy*, contexto especial, processamento de imagens, fuzzy set theory, spatial context, image processing.

### 1. Introdução

A natureza imprecisa dos dados sensoriamento remoto confere certo grau de incerteza inerente ao processo de aquisição dos mesmos. A degradação dos sensores, a transmitância atmosférica, as condições de iluminação, a geometria de aquisição e a forma com que cada tipo de material interage com a radiação eletromagnética são modelados com ao menos algum grau de incerteza estatística associada (Foody e Atkinson, 2002). Ao transformar os dados radiométricos recebidos pelos sensores (radiância, reflectância, número digital etc.) em informações com significado prático no mundo real (temperatura, tipo e uso da terra, concentração de determinada substância), as incertezas inerentes aos dados radiométricos são transferidas para os seus dados derivados. Adicionalmente, uma incerteza associada ao método de reconhecimento ou classificação utilizado na conversão, também contribui, em maior ou menor grau, para o aumento da incerteza associada ao dado final (Wang, 1990). Um número considerável de erros no reconhecimento é devido a pixels que apresentam afinidades com muitas classes de informação (Tso e Mather, 2009). Classificadores tradicionais, conhecidos como rígidos, que atribuem um rótulo único a um determinado pixel através de processos padrões não são considerados eficazes no reconhecimento de dados que apresentam ambigüidade considerável. A teoria *fuzzy*, introduzida por (Zadeh, 1965), surge como uma maneira de contornar o problema descrito acima através da quantificação da incerteza ou ambigüidade associada à medida de interesse. Nesse caso, ao invés de determinado pixel pertencer unicamente a uma classe, ele recebe um grau de pertinência a cada uma, que pode ser entendido como um valor de afinidade da variável em questão à cada classe.

O uso cada vez mais freqüente de métodos de classificação *fuzzy* fornece a base para o desenvolvimento de metodologias que se adaptam a esse conceito. Por exemplo, após a classificação é comum que o usuário queira aumentar a qualidade dos resultados através de métodos que apliquem informações de contexto espacial aos dados classificados com o objetivo de refiná-los. Métodos de modelagem de contexto espacial, como campos randômicos de Markov (*Markov Random Fields*), campos randômicos de Gibbs (*Gibbs Random Fields*), relaxação probabilística (Di Zenzo et al., 1987), são desenvolvidos para aplicações em imagens classificadas de forma rígida. Nesse artigo, um método para atribuição de informações de contexto espacial em imagens classificadas por uma abordagem *fuzzy* é proposto e testado através de experimentos com imagens classificadas. O método é baseado em um processo de relaxação semelhante ao proposto em Di Zenzo et al., 1987.

## 2. Definição do método proposto

As metodologias mais comumente aplicadas para implementar informações de contexto espacial são relaxação probabilística e métodos de Markov. Nesse estudo é proposta um ajuste da técnica de relaxação probabilística investigado por Di Zenzo et al. (1987). Segundo essa abordagem, a probabilidade  $p(i,h)$  de um pixel na posição  $i$  pertencer à classe  $\omega_h$  ( $i \in \omega_h$ ) pode ser atualizada em um processo iterativo da seguinte maneira:

$$p^{t+1}(i,h) = p^t(i,h) \frac{1}{L} \left( 1 + (1/8) \sum_{j=1}^n \sum_{k=1}^c r(i,j,h,k) p^t(j,k) \right) \quad (1)$$

onde  $L$  corresponde a um fator de normalização dado por:

$$L = \sum_{h=1}^c \left( 1 + (1/8) \sum_{j=1}^n \sum_{k=1}^c r(i,j,h,k) p^t(j,k) \right) \quad (2)$$

Nas Equações 1 e(2)2,  $c$  representa o número de classes na imagem temática,  $n$  o número de pixels que compõe a vizinhança,  $t$  a iteração atual do processo de relaxação,  $p(j,k)$  a probabilidade de um pixel vizinho na posição  $j$  pertencer à classe  $\omega_k$  ( $j \in \omega_k$ ),  $r(i,j,h,k)$  o coeficiente de compatibilidade que estima a probabilidade de um pixel na posição  $i$  pertencer à classe  $\omega_h$  ( $i \in \omega_h$ ) e seu vizinho na posição  $j$  pertencer à classe  $\omega_k$  ( $j \in \omega_k$ ). O coeficiente de compatibilidade pode ser estimado da seguinte maneira:

$$r(j,h,k) = E \left[ \ln \frac{p(i \in h, j \in k)}{p(i \in h) p(j \in k)} \right] \quad (3)$$

Um método semelhante para calcular o coeficiente de compatibilidade foi proposto por Hsiao e Sawchuk (1989):

$$r(i, j, h, k) = \frac{1}{5} \ln \left( \frac{E[p(i \in h, j \in k)]}{E[p(i \in h)] E[p(j \in k)]} \right) \quad (4)$$

$$V^{t+1}(i, h) = V^t(i, h) \frac{1}{L} \left( 1 + (1/8) \sum_{j=1}^n \sum_{k=1}^c r(i, j, h, k) V^t(j, k) \right) \quad (5)$$

onde  $V^t(i, h)$  representa o grau de pertinência do pixel na posição central  $i$  com respeito a classe  $\omega_h$ , e  $L$  o fator de normalização:

$$L = \sum_{h=1}^c \left( 1 + (1/8) \sum_{j=1}^n \sum_{k=1}^c r(i, j, h, k) V^t(j, k) \right) \quad (6)$$

Para a vizinhança são considerados os oito vizinhos imediatamente próximos<sup>1</sup> ( $n=8$ ) como descrito na

### Figura .

Com os graus de pertinência estão contidos no intervalo contínuo  $[0, 1]$ , mínimo e máximo, respectivamente, no presente caso, diferentemente do que foi investigado em Di Zenzo et al. (1986), onde o processo de relaxação é probabilística porque atualiza os valores das probabilidades para as classes, aqui o processo de relaxação deve ser aplicado a graus de pertinência. Sendo assim, a designação mais apropriada para descrever o processo adaptado é simplesmente o termo relaxação.

A forma modificada para a Equação 4 proposta nesse artigo para estimar os coeficientes de compatibilidade é a seguinte:

$$r(i, j, h, k) = \frac{1}{5} \ln \left( \frac{N(i, j, h, k) / N}{\left( \sum_{h=1}^c N(i, j, h, k) / N \right) \left( \sum_{k=1}^c N(i, j, h, k) / N \right)} \right) \quad (7)$$

onde  $N(i, j, h, k)$  representa a soma (em toda a imagem) dos graus de pertinência à classe  $\omega_h$  do pixel central na posição  $i$  e o grau de pertinência à classe  $\omega_k$  do seu vizinho na posição  $j$ , e  $N$  o número total de pixels na imagem. O termo  $N(i, j, h, k) / N$  estima o valor médio para os graus de pertinência de um pixel na posição  $i$  para a classe  $\omega_h$  e seu vizinho na posição  $j$  à classe  $\omega_k$ . Os

<sup>1</sup> Também chamado de vizinhança de segunda ordem do pixel.

termos  $\left(\sum_{h=1}^c N(i, j, h, k) / N\right)$  e  $\left(\sum_{k=1}^c N(i, j, h, k) / N\right)$  estimam o valor médio para o grau de pertinência à classe  $\omega_h$  para o pixel na posição central e  $\omega_k$  para seu vizinho  $j$ , respectivamente. Em termos probabilísticos, o valor encontrado pela Equação 7 estima a probabilidade de ocorrência dos dois eventos simultaneamente (pixel central  $i \in \omega_h$  e seu vizinho na posição  $j \in \omega_k$ ). Os dois fatores no denominador estimam as duas distribuições marginais. Adicionalmente, foi assumida invariância espacial para o coeficiente de compatibilidade, i.e., a Equação 7 não depende de  $i$ . Neste caso, em termos computacionais, os valores de  $r$  podem ser convenientemente armazenados em uma matriz  $r(8,2,2)$ .

$j_1$	$j_2$	$j_3$
$j_8$	$i$	$j_4$
$j_7$	$j_6$	$j_5$

Figura 1 - Vizinhança considerada para o contexto espacial.

A convergência do processo é alcançada quando a diferença entre os pixels correspondentes das imagens produzidas por duas iterações consecutivas não for consideravelmente alta. A imagem resultante é um mapa de mudanças refinado indicando através de graus de pertinência às mudanças ocorridas na região estudada.

### 3. Experimentos

Experimentos foram executados para dois tipos de aplicações diferentes: o primeiro na filtragem do resultado da aplicação de um método automático de detecção de mudanças, e o segundo para uma imagem multiespectral classificada por máxima verossimilhança Gaussiana. Nos dois experimentos, a intenção era confirmar que, após a aplicação de informações de contexto espacial através da metodologia porposta, a acurácia das classificações foi melhorada.

O primeiro experimento foi realizado com uma imagem *Landsat-TM* de uma região do estado do Rio Grande do Sul constituída por campos de cultivo e alguns reservatórios de água. No processo de detecção foram empregadas duas imagens de datas distintas. A primeira imagem foi adquirida em 1º de Dezembro de 2006 (Figura 2.a) enquanto a segunda foi adquirida em 2 de Fevereiro de 2007 (Figura 2.b). O método para detecção de mudanças utilizado para gerar o mapa de mudanças *fuzzy* (Figura 2.c) está descrito em Zanotta, 2010. A Figura 2.d apresenta o resultado da aplicação do algoritmo proposto com 10 iterações. Comparando as ampliações nas Figuras 2.e e 2.f, é possível notar uma melhora na uniformidade do mapa de mudanças após a aplicação da metodologia proposta, principalmente na redução de regiões isoladas que não apresentavam semelhança com sua vizinhança antes da aplicação do processo.

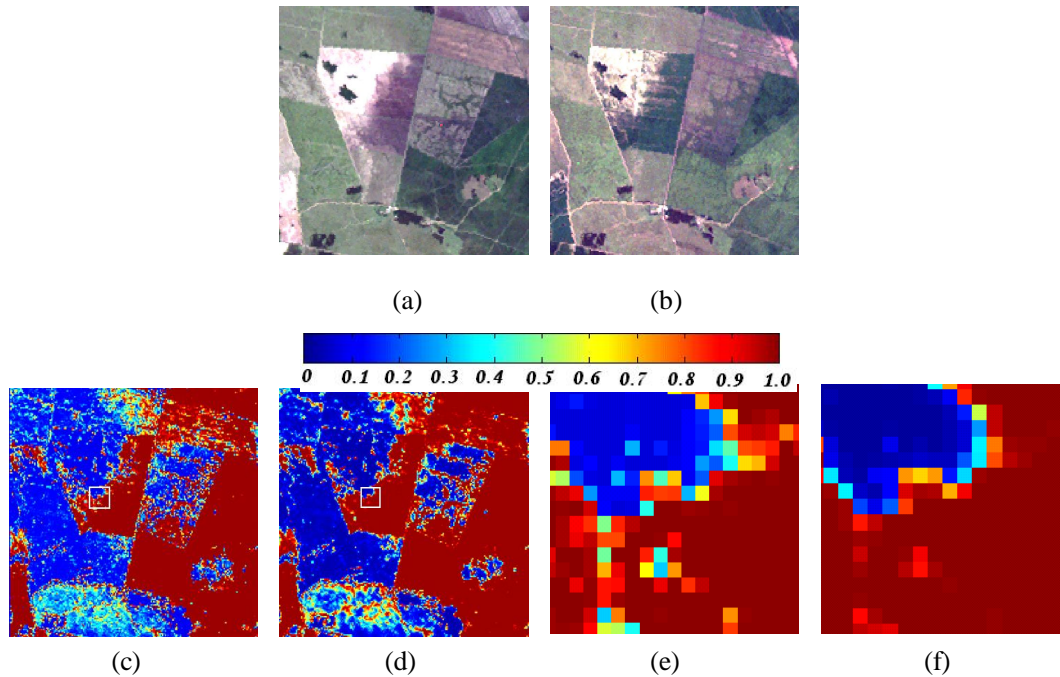


Figura 2. Dados do primeiro experimento (detecção de mudanças): (a) imagem da data 1 (b) imagem da data 2, ambas em composição 3(R) 2(G) 1(B) e graus de pertinência á classe mudança antes (c) e depois (d) da introdução de informações de contexto espacial pelo método proposto após 10 iterações; (e) mostra um detalhe em *zoom* de (c), e (f) o detalhe da mesma área em (d). Os graus de pertinência variam continuamente de zero (azul) até um (vermelho escuro).

O segundo experimento foi realizado com uma imagem do satélite CBERS, sensor CCD, também cobrindo uma área do estado do Rio Grande do Sul. Na cena (Figura 3), existem regiões de solo argiloso (tons marrons), campos (tons verdes), e vegetação densa (tons vermelhos). Uma classificação por um critério de verossimilhança gaussiana foi realizado a partir de amostras colhidas diretamente da imagem. Ao invés de rotular cada pixel a uma ou outra classe, foram atribuídos graus de pertinência a cada uma das classes: solo argiloso, campos e vegetação densa, de modo a gerar um mapa de pertinência de cada pixel para cada classe. O método utilizado para calcular os graus de pertinência a cada uma das classes está descrito em Wang, 1990.




Figura 3. Imagem CBERS-CCD, composição 4(R) 3(G) 2(B), utilizada no segundo experimento.

As Figuras 4.a, 4.e e 4.i mostram os graus de pertinência, variando de 0 (mínimo) até 1 (máximo) para as classes de vegetação densa, campos e solo argiloso, respectivamente. Estas imagens foram submetidas ao processo de relaxação proposto neste trabalho com o intuito de melhorar a qualidade da classificação de acordo com a lógica *fuzzy* adotada. As Figuras 4.b, 4.f e 4.j mostram os resultados obtidos para cada uma das imagens após 10 iterações do processo. Com a ajuda das figuras ampliadas (Figura 4.c, 4.d, 4.g, 4.h, 4.l a 4.m), é possível constatar que regiões que antes apresentavam grande heterogeneidade, passam a apresentar maior uniformidade após a aplicação do método de relaxação proposto.




Figura 2. Dados do segundo experimento (classificação supervisionada por máxima verossimilhança): (a), (e), (i) mapas de pertinência para as classes de vegetação densa, campos e solo argiloso, respectivamente; (b), (f), (j) resultados após a aplicação do método de relaxação proposto; (c), (g), (l) detalhes (antes da aplicação do método) de regiões escolhidas para comparação nos três mapas gerados; (d), (h), (m) mostram os detalhes após a aplicação do processo de relaxação. Os graus de pertinência variam continuamente de zero (azul) até um (vermelho escuro).

#### 4. Conclusões

Neste trabalho, uma técnica fundamentada em um processo de relaxação para inserir informações de contexto espacial em imagens classificadas a partir de uma abordagem *fuzzy* foi proposta e testada a partir de experimentos realizados com imagens reais. Sabendo-se que imagens de sensoriamento remoto, por representarem cenas naturais, possuem certa correlação espacial, após a aplicação do método proposto, é esperado que o resultado da atribuição dos graus de pertinência a cada classe represente melhor a realidade do que os apresentados na classificação original. Os experimentos, que envolveram aplicações para detecção automática de mudanças em imagens multitemporais e uma classificação supervisionada por máxima verossimilhança Gaussiana, mostraram que, após a aplicação do algoritmo de relaxação, as imagens ganharam um aspecto mais uniforme, sem a presença de valores de pertinência descorrelacionados espacialmente. Um número ótimo de iterações do método deve ser escolhido de forma que seja suficiente o bastante para que a ação esperada do processo seja visível, mas que não haja uma uniformização exagerada da imagem, o que deixaria a mesma com um aspecto menos gradativo entre os graus de pertinência máximo (um) e mínimo (zero), muito semelhante a uma classificação rígida entre as classes. A principal diferença entre o método proposto e uma simples filtragem no domínio espacial reside no fato de que a filtragem suavizaria as bordas das grandes regiões, o que não acontece com a aplicação do método iterativo de relaxação.

#### 5. Referências Bibliográficas

Foody, G. M.; Atkinson, P. M. **Uncertainty in Remote Sensing and GIS**, Chichester: Wiley, 2002. 307 p.

Di Zeno, S.; Bernstein, R. DeGloria, S. D., Kolsky, H. G. Gaussian maximum likelihood and contextual classification algorithms for multicrop classification. **IEEE Transactions on Geosciences and Remote Sensing**, v. GE-25, n. 6, p. 805-814, 1987.

Hsiao, J. Y.; Sawchuk, A. A. Supervised Textured Image Segmentation Using Feature Smoothing and Probabilistic Relaxation Techniques, **IEEE Trans. Pattern Anal. Mach. Intell.** v. 11, n. 12, p. 1279-1292, 1989.

Tso, B.; Mather, P. M. **Classification Methods for Remotely Sensed Data**. London and New York: Taylor & Francis, 2001. 332 p.

Wang, F. Fuzzy Supervised Classification of Remote Sensing Images, **IEEE Transactions on Geosciences and Remote Sensing**, v. 28, n. 2, p. 194 – 201, 1990.

Zadeh, L. A. Fuzzy sets. **Information Control**, v. 8, p. 338–353, 1965.

Zanotta, D. C. **Uma abordagem *fuzzy* na detecção automática de mudanças do uso do solo usando imagens de fração e informações de contexto espacial**. 2010. 79 p. Dissertação (Mestrado em Sensoriamento Remoto) – Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Porto Alegre, 2010.